

SVEUČILIŠTE U ZAGREBU

GRAFIČKI FAKULTET

ZAVRŠNI RAD

MARKO SREDNOSELEC



Sveučilište u Zagrebu
Grafički fakultet

Smjer: Tehničko-tehnološki

ZAVRŠNI RAD

PRIMJENA NEURONSKIH MREŽA U TISKARSKIM PROCESIMA

Mentor:

Izv.Prof.Dr.Sc. Dubravko Banić

Student:

Marko Srednoselec

Zagreb, 2016.

SAŽETAK

Kada se govori o inteligenciji najprije se misli na svojstvo vrlo uspješnog snalaženja jedinke u novoj situaciji kao i sposobnost zaključivanja pri rješavanju određenoga problema. Razvitkom čovječanstva razvila se i sama ideja o konstrukciji inteligentnih strojeva koji bi samostalno obavljali određene poslove. Upravo u ovome primjeru javlja se novi pojam, pojam umjetne inteligencije. Sama umjetna inteligencija predstavlja znanstvenu disciplinu koja se bavi izgradnjom sustava čije se ponašanje tumači kao inteligentno. Uz umjetnu inteligenciju potrebno je povezati pojam neuronskih mreža, jednu od metoda umjetne inteligencije. Naime, primjena neuronskih mreža u dvadeset i prvome stoljeću je poprimila enormne razmjere, od zdravstva pa sve do poslovanja i obrazovanja. Cilj ovoga rada je istražiti važnost neuronskih mreža i umjetne inteligencije kao i njihovu poveznicu te usredotočiti se na primjenu neuronskih mreža u tiskarskim procesima.

Ključne riječi: umjetna inteligencija, neuronske mreže, tehnologija, tiskarski procesi

SUMMARY

When we talk about intelligence is first thought to feature a very successful reference specimens in the new situation as well as the abilities of reasoning to solve a particular problem. The development of mankind has evolved and the idea of the design of intelligent machines that independently performed certain tasks. It is in this example, there is a new concept, the concept of artificial intelligence. The very artificial intelligence is a scientific discipline that deals with the construction of systems whose behavior is interpreted as intelligent. With artificial intelligence is necessary to connect the concept of neural networks, one of the methods of artificial intelligence. The application of neural networks in the twenty-first century has taken on enormous proportions, from health through to business and education. The aim of this paper is to investigate the importance of neural networks and artificial intelligence as well as their link and focus on the application of neural networks in the printing process.

Ključne riječi: artificial intelligence, neural networks, technology, printing processes

SADRŽAJ

1. UVOD.....	1
2. INTELIGENCIJA.....	3
2.1. Umjetna inteligencija.....	4
2.1.1. Pojam i definicija umjetne inteligencije	5
2.1.2. Povijesni razvoj umjetne inteligencije.....	5
2.1.3. Područja primjene.....	8
2.2. Neuronske mreže	12
2.2.1. Pojam i definicija neuronske mreže.....	13
2.2.2. Povijesni razvoj neuronskih mreža	13
3. VRSTE NEURONSKIH MREŽA.....	15
3.1. Biološke neuronske mreže	15
3.2. Umjetne neuronske mreže	16
3.3. Prednosti i nedostaci neuronskih mreža.....	18
4. UPOTREBA NEURONSKIH MREŽA U TISKARSKIM PROCESIMA	20
5. ZAKLJUČAK.....	23
6. LITERATURA	24
POPIS SLIKA.....	27
POPIS TABLICA	28

1. UVOD

Razvitkom tehnologije pokušavalo se doći do novih spoznaja i otkrića. Tijekom razvoja čovječanstvo je oduvijek zanimala tema konstrukcije inteligentnih strojeva koji bi određene poslove obavljali umjesto ljudi. Samim time došlo je do razvitka umjetne inteligencije koja označava pojam koji podrazumijeva da pojedini neživi sustav pokazuje sposobnost snalaženja u novim situacijama. Uz pojam umjetne inteligencije sasvim je logično povezati i pojam neuronskih mreža, odnosno mreža koje predstavljaju jednu od metoda umjetne inteligencije. Njihova uspješna primjena očituje se u mnogim znanostima od medicine pa sve do elektrotehnike. Cilj ovoga rada je prikazati primjenu neuronskih mreža u procesima tiskanja.

Kod izrade ovoga rada koristit će se nekoliko različitih znanstvenih metoda. Metodom kompilacije bit će razrađen teorijski dio rada na način da će se prikupljanjem adekvatne literature, odnosno njezinom analizom i sintezom, stvoriti ključna poglavlja u završnom radu. Prilikom odabira glavnih naslova unutar literature koristit će se deduktivna i induktivna metoda. Još jedna znanstvena metoda koja će biti upotrebljena prilikom izrade rada je metoda diskripcije. Ona će se upotrijebiti za samu interpretaciju ponuđenih podataka koji su dobiveni istraživanjem.

Provest će se i istraživanje za stolom s ciljem sakupljanja potrebnih podataka za izradu analiza na temelju kojih će se izvršiti pisanje ovog rada. Komparativna, statistička te matematička metoda u radu poslužit će za izradu grafova i tablica te za kalkulaciju i pravilnu interpretaciju podataka koji su relevantni za donošenje zaključaka na temelju istraživanja.

Također, provest će se i istraživanje za stolom s ciljem sakupljanja potrebnih podataka za izradu analiza na temelju kojih će se izvršiti pisanje ovog rada.

Rad se sastoji od nekoliko temeljnih dijelova. U uvodnom dijelu riječ je o inteligenciji, točnije o umjetnoj inteligenciji, njezinom pojmu i definiciji iste. Prikazan je također i povijesni razvoj kao i područja primjene umjetne integrigencije.

Uz pojam umjetne inteligencije nadvezuje se pojam neuronskih mreža stoga je nastavak rada posvećen istima. U nastavku slijedi pojam i definicija neuronskih mreža kao i povijesni razvoj istih. Slijedeće poglavlje govori o vrstama neuronskih mreža, odnosno o biološkim te umjetnim neuronskim mrežama kao i prednostima i nedostacima navedenih. U ključnom poglavlju prikazana je upotreba neuronski mreža u tiskarskim procesima. Na kraju rada je zaključak u kojem su dani svi relevantni zaključci koji su dobiveni istraživanjem adekvatne literature te pisanjem ovoga rada.

2. INTELIGENCIJA

Ukoliko se govori o inteligenciji, govori se o vrlo općenitome pojmu koji obuhvaća brojne definicije. Inteligencija se može definirati kao svojstvo uspješnoga snalaženja jedine u novim situacijama, ali i ako opća sposobnost zaključivanja pri rješavanju određenih problema. Inteligencija se definira i kao svrsishodno te prilagodljivo ponašanje u danim okolnostima [1]. Definiranje inteligencije je dakle općenito i može se reći kako svojstvena definicija inteligencije ne postoji.

Riječ inteligencija dolazi od krojena latinske riječi intelligere što znači shvaćati, razumijevati te razabrati. Može se reći kako je inteligencija sama po sebi zapravo kombinacija urođenih karakteristika te iskustva učenja [2]. Ona je potencijal koji se ne mora nužno razviti u sposobnost, a moguće ju je povezati i sa brzinom učenja. Kada se govori o inteligenciji potrebno je navesti i nekoliko vrsta inteligencije [3] (tablica 1).

Tablica 1. Vrste inteligencije

REDNI BROJ	VRSTA INTELIGENCIJE
1.	Lingvistička
2.	Logičko – matematička
3.	Prostornotjelesno - kinestetička
4.	Glazbena
5.	Interpersonalna
6.	Intrapersonalna
7.	Prirodna

Izvor: Posavec (2010.) *Višestruke inteligencije u nastavi- Život i škola. Vol. 24, No. 2, str. 55*

2.1. Umjetna inteligencija

Kako bi se okarakterizirala, umjetna inteligencija se može definirati kao disciplina koja se bavi oblikovanjem inteligentnih sustava, odnosno sustava koji implementiraju ona svojstva ljudskog ponašanja koja bi se smatrala inteligentnima.

Naime, umjetna inteligencija je zamišljena kao kombinacija inženjerstva te znanosti i to iz razloga kako bi se izgradili strojevi koji bi bili sposobni koristiti inteligenciju te inteligentno ponašanje. Prema specifičnoj podjeli umjetna inteligencija se može podijeliti na četiri tipa, a to su [4]:

- Slaba
- Jaka
- Primjenjiva
- Kognitivna

Zagovornici slabe umjetne inteligencije su oni koji razvijaju inteligentne sustava kojima se dodaju određena svojstva ljudskoga ponašanja. Za razliku od njih, zagovornici jake umjetne inteligencije su oni koji smatraju kako je moguće stvoriti sustave u kojima će se moću replicirati sva svojstva ljudskoga ponašanja koja se smatraju inteligentnima. Nadalje, primjenjiva umjetna inteligencija je tip inteligencije koji je usmjeren na komercijalne pametne sustave kao što je primjerice sigurnosni sustav koji prepoznaje lice osobe kojoj nije dozvoljen ulazak u zgradu. Naposljetku, kognitivna umjetna inteligencija je ona u kojoj se računala koriste da testiraju teorije na koji način i kako funkcionira ljudska svijest.

„Drugim riječima, inteligencija se očituje u odnosu na neki posebni društveni i kulturni kontekst. S takvom definicijom, kako se može shvatiti inteligenciju zvanu umjetnom? U čemu se nalazi svoja umjetnost? Zasigurno, pridjev umjetna je lako razumjeti, jer taj tip inteligencije je rezultat procesa koji je čovjek stvorio.“ [5]

2.1.1. Pojam i definicija umjetne inteligencije

Kao i sama inteligencija pa tako i umjetna inteligencija je pojam koji ima brojne definicije. Može se krenuti s definicijom koja je karakterizira kao znanstvenu disciplinu koja se bavi izgradnom računalnih sustava, odnosno sustava čije se ponašanje može tumačiti kao inteligentno. Umjetna inteligencija svakako je znanost o tome na koji način postići određeni stroj da izvodi zadatak koji bi u slučaju da ga izvodi čovjek zahtijevao inteligenciju [6].

Dakle, umjetna inteligencija je zapravo pojam koji pod svojim okriljem podrazumijeva svaki neživi sustav, tj. sustav koji pokazuje sposobnost snalaženja u novoj situaciji.

Upravo ovakav sustav je tip sustava koji zahtjeva kompleksan i visok stupanj računalne obrade stoga ne čudi da je realizacija istih u prošlosti bila nemoguća. Tek zadnjih tridesetak godina dolazi do enormnog razvoja umjetne inteligencije.

2.1.2. Povijesni razvoj umjetne inteligencije

Razvoj umjetne inteligencije u početku je tekao može se reći vrlo sporo, no kada je umjetna inteligencija doživjela svoj vrhunac, njezin daljnji uspjeh i razvitak je tekao vrlo brzo. Sam razvoj umjetne inteligencije moguće je podijeliti u pet određenih faza, a to su slijedeće [7]:

1. Faza inkubacije
2. Faza ranog entuzijazma s očekivanjima
3. Faza sustava temeljenih na znanju
4. Faza u kojoj umjetna inteligencija postaje industrijom
5. Faza povratka neuronskih mreža



Slika 1. Razvoj umjetne inteligencije kroz vremenski presjek


Izvor: Dalbelo Bašić (2013.) Online: Umjetna inteligencija,
<http://www.fer.unizg.hr/predmet/umjint/materijali> (16.08.2016.)

Početak razvoja umjetne inteligencije podrazumijeva se godina 1943. Tada je predstavljen prvi model umjetnoga neurona, odnosno model koji je nastao istraživanjem neurofizioloških karakteristika živih bića. Navedeni model funkcionirao je na principu aritmetičko – logičkoga elementa te je uključivao apsolutno sve sastavnice koje su bile potrebite za provođenje logičkih operacija. U ovoj fazi bila je vrlo važna implementacija modela umjetnoga neurona s obzirom da je upravo u to vrijeme računalna tehnologija bila u počecima razvoja [8].

U ovoj fazi očekivanja u neuronskim mrežama nisu bila ispunjena te je unatoč ogromnome napretku umjetne inteligencije smatrano kako nikada u potpunosti neće biti ostvarena. Nakon navedenoga slijeda umjetna inteligencija, točnije njezin razvoj odvijao se u dva smjera, a to je psihološko i fiziološko proučavanje ljudskoga uma te tehnološki razvoj sofisticiranih računalnih sustava.

Daljnim razvitkom pedesetih godina dvadesetog stoljeća, neuronske mreže su bile te koje su obilježile razdoblje. Upravo je navedenih godina predstavljena vizija računalnoga modela u kojem je temeljni princip bio oponašanje funkcioniranja mozga. Ovakav jednostavan model neuronskih mreža prozvan je perceptron.

Umjetna inteligencija kao i neuronske mreže i dalje su bilježile svoj razvitak. Prvu polovicu dvadesetoga stoljeća zaobilježio je i matematičar Alan Mathison Turing koji je razvoju umjetne inteligencije doprinio postavljanjem teorije Turingova testa. Isti je napravljen kao igra u kojoj se provjerava teza da li računala mogu misliti. Test ima tri sudionika. Prvi ispitanik je čovjek, drugi računalo, a ispitivač je također čovjek. Ispitivač je taj koji se nalazi u odvojenoj prostoriji od samoga ispitanika. Njegova je uloga zapravo procijeniti da li je ispitanik čovjek ili pak računalo, a o istome odlučuje na temelju primljenih odgovora koje je postavio. Ukoliko je računalo uspijelo zavarat ispitivača ustvrdilo bi se da je stroj inteligentan [9].



Slika 2. Turnigov test

Izvor:

https://upload.wikimedia.org/wikipedia/commons/e/e4/Turing_Test_version_3.png
(15.08.2016.)

Daljnim razvojem umjetne inteligencije razvijali su se različiti stručni ili pak ekspertni sustavi. Njihove glavne karakteristike bile su rješavanje jednostavnih problema i to jednako dobro kao i ljudi. Navedeni sustavi sastojali su se od baze znanja te mehanizama zaključivanja kao i korisničkog sučelja koje je služilo za komunikaciju između stroja i čovjeka. Ovakvi strojevi svoju primjenu najprije su pronašli u matematici, a potom u pravu, vojnim te medicinskim znanostima.

Nakon devedesetih godina dvadesetog stoljeća kreće nagli razvoj. Veliki napredak bilježi se u područjima umjetne inteligencije poput obrade te razumijevanja prirodnoga jezika te strojnog učenja i robotike.

2.1.3. Područja primjene

Umjetna inteligencija zauzima mjesto u brojnim područjima primjene. Naime, područja koja se bave istraživanjem umjetne inteligencije su primjerice: filozofija, matematika, ekonomija, psihologija, lingvistika, biologija te računalstvo. Kao što je vidljivo naveden je širok spektar znanosti.

Umjetna inteligencija je pojam koji obuhvaća brojna područja primjene, kao što su primjerice [10]:

- Ekspertni sustavi
- Formalizni i metode znanja
- Učenje
- Razumijevanje i obrada prirodnih (i umjetnih) jezika
- Rješavanje problema i metode pretraživanja
- Robotika
- Automatsko programiranje
- Računalni vid, raspoznavanje uzoraka i analiza scene
- Umjetne neuronske mreže i genetski algoritmi

1. Ekspertni sustavi

Kao prvo navedeno su ekspertni sustavi, odnosno računalni programi koji sadrže određena specifična znanja iz jendoga ili pak više znanosti. U najčešćem slučaju oblik ekspertnog sustava sastoji se od određenoga seta pravila prema kojima se analiziraju informacije o specifičnoj vrsti problema, ali i pružanja matematičke analize problema. Naime, upravo ovisno o izvedbi pružaju korisniku povratne informacije koje je potrebno poduzeti kako bi se riješio problem [11].

Ovakav tip sustava pomaže prilikom organizacija koje imaju vrlo visok nivo iskustva kao i znanja u direktnome te pravilnome rješavanju problema koje je isključivo teško prenijeti na druge članove kao iste organizacije. Ekspertni sustavi su stvoreni kako bi riješavali probleme i zadatke u područjima medicine, financiranja, proizvodnje, ali i računovodstva.

2. Formalizmi i metode prikaza znanja

Slijedeća stavka su formalizmi kao i metode prikaza znanja. Znanje je naime logički pregled činjenica kao i generalizacija o objektivnoj stvarnosti koju je čovjek usvojio te trajno zadržao u svojoj svijesti. Predstavlja ukupnost svega što je poznato u određenome polju, sve činjenice i informacije, odnosno svjesnost te familijarnost koja je stečena iskustvom određene činjenice ili pak situacije.

Naime, znanje se koristi kako bi se postiglo inteligentno ponašanje, a glavni cilj prikaza znanja je predstaviti znanje na način da se zaključci izvlače iz već postojećega znanja. Ovdje je prikaz znanja problem koji izniče u kognitivnoj znanosti, a predstavlja način na koji ljudi pohranjuju te obrađuju informacije te umjetnoj inteligenciji u kojoj je primarni cilj pohrana znanja na način da računalni program može obraditi i oponašati ljudsku inteligenciju [12].

3. Učenje

U navedenim područjima primjene spominje se i učenje. Potrebno je naglasiti kako postoji više razlilitih oblika učenja koji su primjenjeni u pojmu umjetne inteligencije. Najjednostavniji od njih je svakako oblik učenja na greškama preko pokušava.

U ovome slučaju najjednostavniji računalni program kao program za rješavanje matiranja u jednom potezu u šahu, istražuje mat pozicije slučajnim potezima. U onome trenutku kada je rješenje pronašeno, program pamti poziciju te je koristi slijedeći put kada se nađe u identičnoj situaciji.

4. Razumijevanje i obrada prirodnih i umjetnih jezika


Umjetna inteligencija koristi se i pri razumijevanju i obradi prirodnih, ali i umjetnih jezika. U filozofiji jezika prirodni ili pak obični jezik je jezik kojime se govori, piše ili pak simbolički označava, dok su umjetni jezici oni jezici čija su gramatička obilježja svjesno planirana, odnosno nisu stvorena prirodnim putem.

5. Rješavanje problema i metode pretraživanja

Rješavanje problema kao i metode pretraživanja u umjetnoj inteligenciji karakteristične su po traženju u rangu mogućih akcija, odnosno s ciljem pronalaženja ranije definiranoga rješenja. Naime, metode rješavanja se dijele na one posebne te opće namjene. Prva navedena metoda je metoda traženja adaptiranog rješenja za određeni problem te sadrži vrlo specifične osobine situacija od kojih se sama sastoji. Suprotno navedenome, metoda opće namjene je metoda koja se primjenjuje na širi spektar problema. Koristi se u umjetnoj inteligenciji i metoda je krajnje analize, odnosno dio po dio, reduciranje razčitosti između trenutnoga stanja i krajnjega cilja [13].

6. Robotika

Umjetna inteligencija svoju primjenu ima svakako i u robotici, znanosti koja predstavlja spoj strojeva kao i računalne tehnike. Umjetna inteligencija se u ovome slučaju bavi proučavanjem strojeva koji mogu na neki način zamijeniti čovjeka u izvršavanju određenih zadataka.



Slika 3. Primjena umjetne inteligencije u robotici

Izvor: <http://www.ictbusiness.info/media/ilustracije/ilustracija-shutterstock-robot-ai-umjetna-inteligencija.jpg> (14.08.2016.)

7. Automatsko planiranje

Automatsko planiranje je tip programiranja. Ono se oslanja na automatsko generiranje programa i to na osnovu korisničkih zahtjeva. Kao i navedeno i automatsko planiranje dio je primjene umjetne inteligencije.

8. Računalni vid

Umjetna inteligencija svoju primjenu ima i u računalnome vidu, području umjetne inteligencije koje se bavi prepoznavanjem dvodimenzionalnih ili pak trodimenzionalnih predmeta. Ovo područje obuhvaća metode za stjecanje, obradu, analiziranje te razumijevanje slike.

9. Neuronske mreže i genetski algoritmi

Umjetna inteligencija veže se uz pojam neuronskih mreža i genetskih algoritama. Razvojem umjetnih neuronskih mreža došlo je do velikoga napretka u području umjetne inteligencije.

Dolazi do povećanja projektiranja neuronskih mreža u svrhu rješavanja problema kao što je primjerice prepoznavanje, predviđanje, optimizacija, asocijativna memorija te kontrola. Potrebno je naglasiti kako su se genetski algoritmi počeli razvijati šezdesetih godina dvadesetog stoljeća i to kao reakcija na top-down pristup koji je koristila većina ljudi koji su se bavili istraživanjima koja su bila vezana za umjetnu inteligenciju [14].

2.2. Neuronske mreže

Kao i umjetna inteligencija pa tako i neuronske mreže imaju brojne definicije. Ovdje je riječ pak o dvojakome značenju. Postoje prirodne i umjetne neuronske mreže.

2.2.1. Pojam i definicija neuronske mreže

Neuronske mreže su mreže koje nastoje pronaći određenu vezu između aktivnosti pojedinog neurona te promjena koje se događaju na sinapsama s mišljenjem, percepcijom pa tako i samim pamćenjem.

Ovim, neuronskim mrežama na najbolji se način nastoji pokušati povezati spoznaja o samome radu živčanoga sustava. S obzirom da je živčani sustav evolucijom oblikovan na način da rješava probleme koji su ključni za preživljavanje tako i umjetna neuronska mreža se opisuje kao preslika ljudskoga mozga s kojom se pokušava stimulirati postupak samog učenja. Neuronska mreža je zapravo skup povezanih jednostavnih elemenata čija se funkcionalnost temelji na biološkom neuronu [15].

2.2.2. Povijesni razvoj neuronskih mreža

Povijesni razvoj neuronskih mreža proteže se u nekoliko ključnih godina. Godine 1943. Warren Sturgis McCulloch kao i Walter Pitts postavili su temelje za razvoj neuronskih mreža. Naime ukazali su na to da neuroni mogu imati dva stanja, odnosno pobuđujuće i umirujuće. Samim time došli su do zaključka kako aktivnost neurona ovisi o pragu vrijednosti.

Šest godina kasnije, Donald Olding Hebb je predložio svojevrsno pravilo kojim je opisan proces učenja. Upravo navedeno pravilo smatra se jednim od bitnijih doprinosa za razvoj teorije neuronskih mreža.

Godine 1956. Nathaniel Rochester na konferenciji Dartmouth Summer Conference predstavlja prvu stimulaciju Hebb-ovog modela koji je bio preteča modela neuronskih mreža.

Godine 1958. John von Neuman ukazao je na to da u središnjem živčanome sustavu postoje različite logičke strukture i to u odnosu na one koje čovjek koristi u matematici kao i logici [16].

Godine 1958. Frank Rosenblatt je kao što je već spomenuto izumio perceptron, element koji je sličan umjetnome neuronu, a dvije godine kasnije Bernard Widrow te Marcian Hoff razvili su pravilo učenja kojim je omogućeno minimiziranje kvadrata odstupanja tijekom širenja mreže.

Godine 1974. razvijena je višeslojna perceptron mreža dok je šest godina kasnije razvijena nova neuronska mreža, odnosno neocognitor.

3. VRSTE NEURONSKIH MREŽA

Prema osnovnoj podjeli neuronskih mreža, postoje dva tipa istih, a to su:

- Biološke neuronske mreže
- Umjetne neuronske mreže

3.1. Biološke neuronske mreže

Ukoliko se na pojam gleda tradicionalno, on se odnosi na biološku, tj. prirodnu neuronsku mrežu koja je građena od bioloških neurona. Navedeni su povezani u periferni ili pak središnji živčani sustav. Živčana stanica, neuron, osnovna je jedinica živčanog sustava, a samim time je i najsloženija jedinica ljudskoga organizma. Prema funkciji razlikuje se preko sto vrsta neurona koji su raspoređeni prema jasno definiranom rasporedu. Neuron je građen od tijela stanice te brojnih dendrita i aksona.


Dendriti označuju kraće živčane produžetke koji prenose živčane impulse s osjetilnih organa do tijela same stanice. Aksoni su pak tanke cjevčice čiji je jedan kraj povezan s tijelom neurona, a drugi kraj se dijeli na niz grana.

„Mozak je načinjen od neurona, a neuroni su visoko razvijene stanice, nevjerojatno lijepe i složene. Ipak, nisu smisleni sami po sebi – korisni su jedino kada 'rade' zajedno u mreži ili krugu. Svaki neuron može djelovati u različitim neuronskim grupama. Neuronski krugovi mogu biti smisleni na jedan od ova tri načina:

1) tako da nam izravno omogućuju smisleno iskustvo (kretanje, vid, sluh, emocije, temperatura itd.)

2) tako da tom smislenom iskustvu daju strukturu (tzv. kognitivni primitivi: predodžbene sheme, x-scheme, sheme dinamike sile)

3) tako da povezuju neuronske podsustave (vezni krugovi / linking circuits). “[17]



Slika 4. Građa neurona

Izvor: <http://webspace.ship.edu/cgboer/neuron.gif> (15.08.2016.)

Sinapsa je mjesto, tj. razmak koji se nalazi između završetka aksona prethodnog neurona i dendrita slijedećeg. Zahvaljujući neuronima ljudski mozak postiže iznimnu brzinu kao i sposobnost realizacije raznih zadataka istovremeno. Preko sinapse signali s jednog neurona na drugi putuju električnim ili pak kemijskim putem.

3.2. Umjetne neuronske mreže

Osim prirodne neuronske mreže postoji i umjetna neuronska mreža. Navedene mreže u ovome slučaju sagrađene su od umjetnih neurona, a služe za razumijevanje bioloških neuronskih mreža re rješavanje problema na područjima umjetne inteligencije. Umjetne neuronske mreže se koriste strukturama ljudskoga mozga. Na taj način pokušavaju primjerenu strategiju analize podataka. U ovome slučaju neuronske mreže su te koje pronalaze široku primjeu ne samo u tehničkim, nego i u društvenim znanostima.


Umjetne neuronske mreže se uspješno primjenjuju u različitim područjima kao što je poslovanje, vojska, financije ili pak elektrotehnika. Postoje brojni primjeri, a neki od njih su:

- Financije (procjena rizika)
- Pretvaranje teksta u govor
- Obrada signala
- Određivanje problema kod rada avio-motora
- Otkrivanje eksploziva u prtljazi na aerodromu
- Marketing (segmentiranje kupaca)
- Određivanje tipova oblaka na temelju satelitskih snimki
- Prepoznavanje govora

Danas, vrlo popularne umjetne neuronske mreže imaju određena svojstva kojima se ističu. Naime, neuronske mreže omogućuju paralelnu obradu informacija. Informacije bivaju spremljene u neuronsku mrežu te su raspodjeljene na više jedinica. Vrlo važno svojstvo je i svojstvo redundantnosti, odnosno svojstvo otpora na kvar. Neuronska mreža sposobna je raditi čak i ukoliko se uništi jedan njezin dii.

Vrlo bitno svojstvo neuronske mreže je učenje te adaptacija. Ove dvije navedene stavke neuronsku mrežu čine vrlo sposobno obrađivati neprecizne podatke u nestrukturiranom kao i neodređenom okruženju.

Neuronske mreže su viševarijabilni sustavi. Njih karakterizira vrlo laka primjena za modeliranje kao i upravljanje viševarijabilnim procesima. Neuronske mreže su također i univerzalni aproksimatori. One mogu imati mogućnosti aproksimiranja i to proizvoljne kontinuirane nelinearne funkcije i to do željene točnosti.



Slika 5. Umjetne neuronske mreže

Izvor: https://upload.wikimedia.org/wikipedia/commons/thumb/9/91/Multi-Layer_Neural_Network-Vector.svg/langnone-250px-Multi-Layer_Neural_Network-Vector.svg.png (16.08.2016.)

Umjetni neuron je neuron kod kojega je svakom signalu pridodan numerički iznos. Kod umjetnog neurona na ulaz u sam neuron signali se množe s težinskim faktorom koji se opisuje kao jakost sinapse. Ovi rezultati koji se dobiju množenjem signala te težinskih faktora se zbrajaju te ukoliko dobiveni iznos prelazi definirani prag, neuron daje izlazni signal. Neuron može imati i neku drugu funkciju osim funkcije praga kao što je primjerice prijenosna funkcija.

„Umjetna neuronska mreža je sustav temeljen na radu biološke neuronske mreže, drugim riječima, ona predstavlja oponašanje biološke neuronske mreže.“ [18]

3.3. Prednosti i nedostaci neuronskih mreža

Neuronske mreže imaju svoje određene prednosti, ali i nedostatke. Prednost neuronske mreže naspram tradicionalne svakako je paralelna obrada koja je kod tradicionalnog računalstva uzastopna.

Nadalje, neuronske mreže su mreže koje imaju distribuiranu asocijativnu memoriju, odnosno njihova memorija je predstavljena težinama među neuronima, a sama vrijednost težina predstavlja stanje znanja u mreži.

Neuronske mreže su mreže koje karakterizira sposobnost prepoznavanja uzroka i to u većem stupnju od bilo kojih tradicionalnih statističkih sustava. Ovaj tip mreža može raditi s nejasnim te manjkavim podacima koji su tipični za podatke iz različitih senzora.

Neuronske mreže su mreže koje mogu sintetizirati vrlo složene kontinuirane funkcije. Mogu stvarati vlastite odnose na podacima te oblikovati znanje učeći na razno raznim primjerima [19]

Kao nedostatak neuronskih mreža ističe se da za uspješno učenje je ipak potreban prevelik broj podataka. Nadalje, mreže nisu nažalost u mogućnosti dati vrlo zadovoljavajuće rješenje izvan raspona vrijednosti iz kojih uče. Također, kod neuronskih mreža generalizacija naučenih primjera uspješna je jedino kod neprekidnih pojava [20].

4. UPOTREBA NEURONSKIH MREŽA U TISKARSKIM PROCESIMA

Neuronske mreže imaju vrlo široko područje primjene tako da ne čudi kako se njihova primjena odvija i u tiskarskim procesima. Naime, neuronske mreže mogu se koristiti i kao sastavni dio tiskarskog poduzeća, odnosno za izradu sustava kalkulacija. Kako bi jedna tiskara mogla uopće predložiti klijentu ponudu za neki proizvod potrebno je sastaviti tiskarsku kalkulaciju koja podrazumijeva organizaciju cjelokupnog procesa od pripreme tiska pa sve do dorade kako bi se klijentu isporučila ponuda za gotov proizvod.

Sam izračun troškova izrade proizvoda je temelj zapravo za ekonomski isplativo te održivo poslovanje tvrtke. Naime, ukoliko su troškovi pogrešno predviđeni te se kalkulacija odradila s netočnim ulaznim podacima sama ponuda je previsoka u odnosu na samu konkurenciju. Zbog navedene greške moguće je izgubiti vrlo isplativ posao, a samim time i cijena s kojom se posluje biva premala.

Kalkulacija ponude:

Nova kalkulacija Kalkulacija br.: 160 Na osnovu upita br.: 81 Naručitelj: SOFTECH Kopiraj! 0 Vidi upit... 305

Opis proizvoda/usluge: Plakat DDC corp Dorada: rezati
Naklada: 500 kom. Priprema:
Opseg:
Format: 50x70
Materijal: Kunstdruck B1 135 gr sjajni
Tisak: 4/0
Potrebna korektura:
Naručitelj Izvođač
Da Ne
Izraditi do:
Rok izrade opis:

Proizvod: Plakat DDC corp Kataloški broj:
Tražena naklada: 500 kom.
Uzeti sa skladišta: 0 Za rezervirati: 0 Sve
Razlika za kalkulaciju (izradu): 0
Broj listova iz arkat: 0
Rezerviraj
Rezervacije proizvoda
Količina Nabavna cijena
0,00 0,00
Ukupna količina i nabavna vrijednost:

A - Troškovi materijala	Naziv	Količina i mjera	Ref. mjera	Jed. cijena	Total	Napomene
Papir (ljepnika, platno)	Kunstdruck B1 135 gr sjajni	250,00 KOM	=	0,00	1,12	280,00
Vrsta:	OFFSET PLOČA ROLAND 605x740	4,00 KOM	=	0,00 Kg	19,44	77,76
	BOJA CRNA 80 B 63	0,20 KG	=	0,00 Kg	52,00	10,40
	BOJA CRVENA 80 B 61	0,20 KG	=	0,00 Kg	52,00	10,40
Ploče dimenzija	BOJA PLAVA 80 B 62	0,20 KG	=	0,00 Kg	52,00	10,40
Film/paus:	BOJA ŽUTA 80 B 60	0,20 KG	=	0,20 Kg	52,00	10,40
Boja:	*		=			
Ljepilo:						
Pomoćni materijali:						
Ukupno materijal:					399,36	
B - Usluge drugih	Naziv usluge drugih	Količina i mjera	Jed. cijena	Total	Napomene	
Opis tuđih usluga i cijene:	PRIPREMA	1,00 0	500,00	500,00		

Slika 6. Kalkulacija ponude

Izvor: <http://www.softech.hr/Upload/LargeImages/Tiskara1.png> (17.08.2016.)

Svakako niti jedan od navedenih slučajeva nije niti malo povoljan te se mora pažljivo postaviti norma za izradu kalkulacija. Ovdje se uključuje brzina strojeva. Postupak nadalje opisuje osoba zadužena za izradu kalkulacija u tiskari:

„Preveliki višak povećava troškove pa će, u slučaju da smo u kalkulaciji predvidjeli preveliki višak, cijena koju damo biti veća nego što je trebala. Ukoliko je višak koji smo predvidjeli premali moguće je da na kraju proizvodnje nemamo dovoljno gotovog proizvoda za isporuku pa je potrebno ponavljati proizvodnju manjeg dijela narudžbe, što sa sobom nosi velike, nepredviđene troškove.

Druga je opcija da smo prije proizvodnje vidjeli da je višak s kojim je rađena kalkulacija premali pa moramo za narudžbu izdati materijal koji kalkulacijom nije predviđen te na taj način ponovno imamo povećane troškove proizvodnje i smanjujemo zaradu.

Izračun optimalnog tehnološkog viška ovisi o velikom broju parametara i vrlo je dobro ukoliko normu za tehnološki višak možemo izraditi iz čim je više moguće ulaznih podataka prikupljenih u proteklim proizvodnjama sličnog proizvoda.

Višak koji će nam biti potreban ovisi o veličini nakalde, veličini proizvoda, vrsti materijala, složenosti posla, broju i zahtjevnosti potrebnih operacija, ali i stroju na kojem se pojedine operacije izvode te često i o djelatniku koji neku operaciju obavlja. Neke od ovih parametara lakše je predvidjeti i normirati od nekih drugih, kao što je utjecaj djelatnika na količinu utrošenog viška.

Također, puno je lakše predvidjeti koliko će viška biti potrebno za namještanje strojeva, od onog dijela koji nam služi kao sigurnost u slučaju da dođe do nekih nepredvidivih problema u procesu. S koje god strane gledali, jako je važno da tehnološki višak bude optimalno određen. Prikupljanje i analiza podataka za izračun optimalne količine tehnološkog viška zahtjevan je i dugotrajan posao, a moguće je da i sa analizom velikog broja podataka opet nećemo lako moći odrediti ono što je najoptimalnije za konkretan proizvod.”[21]

Dakle, tiskarske kalkulacije se nalaze unutar radnih naloga. Od izrade kalkulacije pa sve do pakiranja proizvoda operacije su zapisane u radnome nalogu. Prva stranica je kalkulacija, a sastoji se od slijedećih informacija te parametara: [22]

- Naklada za tisak
- Strojevi i štanice koje će se koristiti
- Broj boja apliciranih u tisku
- Operacije u doradi
- Broj transparentnih kutija
- Gramatura i format papira ili kartona
- Boja i format arka za tisak

5. ZAKLJUČAK

Umjetna inteligencija je područje koje danas pokriva različite znanosti i zbilja je vrlo rasprostranjena. Navedena je disciplina koja se bavi oblikovanjem inteligentnih sustava kako bi se implementirala sva svojstva ljudskog ponašanja koja se smatraju inteligentnima. Zamišljena je kao kombinacija znanosti, ali i inženjerstva i to iz razloga kako bi se izgradili strojevi koji su sposobni koristiti inteligenciju te inteligentno ponašanje. Dijeli se na slabu, jaku, primjenjivu te kognitivnu.

Svoje područje primjene je uvelike raširila stoga se pronalazi u područjima filozofije, računalstva, matematike, ali i ekonomije, psihologije, lingvistike te biologije. Umjetna inteligencija, kao i neuronske mreže u najužem smislu mogu pridonijeti vrlo kvalitetnim analizama podataka te ostalim poslovnim procesima a pa tako i u tiskarskim procesima. Ono što je ključno je prilikom svih ispitivanja isprobati što veći broj neuronskih mreža i to kako bi se dobila najkvalitenija mreže, odnosno mreža koja ima najveću pouzdanost.

6. LITERATURA

(1) Šverko, B. (2011.) Psihologija: udžbenik za gimnazije, 5. Izdanje, Zagreb. Školska knjiga

(2) Grgin, T. (2004.) Edukacijska psihologija. 2 izdanje. Zagreb: Slap

(3) Posavec (2010.) Višestruke inteligencije u nastavi- Život i škola. Vol. 24, No. 2, str. 55

(4) Dumančić, S. (2014.) Neuronske mreže. Sveučilište Josipa Jurja Strossmayera u Osijeku

(5) Odilon Gbenoukpo Singbo (2009.) Umjetna inteligencija u suvremenom biokibernetičkom svijetu. Spectrum: ogledi i prinosi studenta teologije, No. 3-4, str. 55

(6) Dalbelo Bašić (2013.)

Online: Umjetna inteligencija, <http://www.fer.unizg.hr/predmet/umjint/materijali>

(7) Dalbelo Bašić (2013.)

Online: Umjetna inteligencija, <http://www.fer.unizg.hr/predmet/umjint/materijali>

(8) Dalbelo Bašić (2013.)

Online: Umjetna inteligencija, <http://www.fer.unizg.hr/predmet/umjint/materijali>

(9) Dalbelo Bašić (2013.)

Online: Umjetna inteligencija, <http://www.fer.unizg.hr/predmet/umjint/materijali>

(10) Umjetna inteligencija. Online: https://www.fer.unizg.hr/_download/repository/UI-1-Uvod.pdf

(11) Umjetna inteligencija.

Online: <https://www.fer.unizg.hr/download/repository/UI-1-Uvod.pdf>

(12) Umjetna inteligencija.

Online: <https://www.fer.unizg.hr/download/repository/UI-1-Uvod.pdf>

(13) Umjetna inteligencija.

Online: <https://www.fer.unizg.hr/download/repository/UI-1-Uvod.pdf>

(14) Umjetna inteligencija.

Online: <https://www.fer.unizg.hr/download/repository/UI-1-Uvod.pdf>

(15) Dumančić, S. (2014.) Neuronske mreže. Sveučilište Josipa Jurja Strossmayera u Osijeku

(16) Dumančić, S. (2014.) Neuronske mreže. Sveučilište Josipa Jurja Strossmayera u Osijeku

(17) Štrkalj Despot, K. (2013.) Od neurona do metafore (i natrag): Neuralna teorija metafore u okviru neuralne teorije jezika i mišljenja. Suvremena lingvistika. Vol. 39. No. 76. str. 160

(18) Mirceska, A., Kulakov, A., Stoleski, S. Uloga umjetne neuronske mreže u detekciji abnormalnosti u funkciji rada pluća. Engineering Review: Međunarodni časopis namijenjen publiciranju originalnih istraživanja s aspekta analize konstrukcija, materijala i novih tehnologija u području strojarstva, brodogradnje, temeljnih tehničkih znanosti, elektrotehnike, računarstva i građevinarstva. Vol. 29, No. 2, str. 1

(19) Dumančić, S. (2014.) Neuronske mreže. Sveučilište Josipa Jurja Strossmayera u Osijeku

(20) Dumančić, S. (2014.) Neuronske mreže. Sveučilište Josipa Jurja Strossmayera u Osijeku

(21) Jelušić, P. B. (2016.) Izrada automatiziranog sustava kalkulacija korištenjem neuronskih mreža. Diplomski rad. Sveučilište u Zagrebu. Grafički fakultet

(22) Jelušić, P. B. (2016.) Izrada automatiziranog sustava kalkulacija korištenjem neuronskih mreža. Diplomski rad. Sveučilište u Zagrebu. Grafički fakultet

POPIS SLIKA

Slika 1. Razvoj umjetne inteligencije kroz vremenski presjek	6
Slika 2. Turnigov test.....	7
Slika 3. Primjena umjetne inteligencije u robotici.....	11
Slika 4. Građa neurona.....	16
Slika 5. Umjetne neuronske mreže	18
Slika 6. Kalkulacija ponude	20

POPIS TABLICA

Tablica 1. Vrste inteligencije	3
--------------------------------------	---